

PRIMJENA POSLOVNE INTELIGENCIJE ZA ANALIZU PODATAKA I PODRŠKU ODLUČIVANJU U POLJOPRIVREDI

Grujica Vico¹, Danijel Mijić², Radomir Bodiroga¹

Izvod: Cilj ovog rada je da se istraže i prezentuju mogućnosti primjene poslovne inteligencije u poljoprivredi. Ukratko je predstavljen pojam poslovne inteligencije, prikazane su neke od primjena u poljoprivredi, kao i mogućnosti za analizu podataka korišćenjem jednostavnijih alata poslovne inteligencije na konkretnom skupu podataka o poljoprivrednim gazdinstvima. Zahvaljujući primjeni tih alata, donosioci odluka imaju mogućnost da samostalno kreiraju poglede na podatke iz različitih perspektiva, te da na vrijeme dobiju informacije bitne za poslovanje, u formi prilagođenoj vlastitim potrebama.

Ključne reči: poslovna, inteligencija, odlučivanje, poljoprivreda, analiza

Uvod

Pravovremeni pristup informacijama jedan je od važnih faktora za uspješno upravljanje preduzećem i donošenje poslovnih odluka. Količina podataka koje je potrebno obraditi za dobijanje korisnih informacija značajno je povećana s obzirom na intenzivniju primjenu informaciono-komunikacionih tehnologija (IKT) u današnjem društvu i sve veći broj izvora podataka. Iz tog razloga, neophodno je koristiti adekvatne alate za efikasnu analizu podataka i dobijanje tačnih i pravovremenih informacija koje mogu pomoći menadžmentu za donošenje ispravnih odluka, kako na operativnom, tako i na strateškom nivou.

Poljoprivreda je oblast u kojoj se primjena IKT svakodnevno povećava, što pokazuju i istraživanja u regionu i svijetu (Moskvins i sar., 2008; Sorensen i Bochtis, 2010; Tejas i Kalpesh, 2015; Ilie i Gheroghe, 2016, Krintz i sar., 2016). Potreba za tehnologijama i alatima za naprednu analizu podataka i otkrivanje znanja iz velikih količina podataka sve je izraženija sa pojavom inteligentnih i relativno jeftinih uređaja i senzora koji mogu da obezbijede skoro konstantno prikupljanje i memorisanje „sirovih“ podataka sa terena, kao što su podaci o stanju zemljišta, usjeva, ili meterološkim prilikama (Celarc i Gros, 2013; Waga i Rabah, 2014; Garg i Aggarwal, 2016). Poslovna inteligencija se nameće kao adekvatno rješenje za analizu podataka i pružanje potrebnih informacija donosiocima odluka na različitim nivoima. Upotrebom alata poslovne inteligencije stvaraju se uslovi za efikasno upravljanje i planiranje kroz analizu činjenica, razumijevanje trenutnog stanja i predviđanje budućih trendova u poslovanju organizacije, što može pozitivno da utiče i na poslovne rezultate.

U ovom radu je ukratko predstavljen koncept poslovne inteligencije i mogućnosti njegove primjene za analizu podataka i podršku odlučivanju u oblasti poljoprivrede.

¹Univerzitet u Istočnom Sarajevu, Poljoprivredni fakultet, Vuka Karadžića 30, Istočno Sarajevo, Bosna i Hercegovina (vicogrujica@yahoo.com);

²Univerzitet u Istočnom Sarajevu, Elektrotehnički fakultet, Vuka Karadžića 30, Istočno Sarajevo, Bosna i Hercegovina;

Kroz jednostavan i praktičan primjer analize podataka o poljoprivrednim gazdinstvima u Republici Srpskoj prikazani su i neki alati koji mogu da se koriste u ovoj oblasti.

Poslovna inteligencija

Poslovna inteligencija predstavlja skup metoda i postupaka za podršku u procesu analize podataka i odlučivanja baziranog na podacima. Pojam poslovne inteligencije prvi put je pomenuo IBM istraživač Hans Peter Luhn u članku iz 1958. godine, u kome je ovaj pojam definisan kao „sposobnost razumijevanja međusobnih veza predstavljenih činjenica na način koji vodi ka ostvarivanju željenog cilja“. Krajem osamdesetih godina prošlog vijeka Howard Dresner je predložio termin poslovne inteligencije čije značenje se odnosilo na „koncepte i metode za poboljšanje procesa odlučivanja baziranog na činjenicama“. Oblast poslovne inteligencije razvila se značajno tokom zadnje dvije decenije i našla primjenu u mnogim oblastima ljudskog života i rada. Danas poslovna inteligencija predstavlja skup alata i metodologija za korišćenje podataka iz skladišta podataka i njihovo pretvaranje u informacije potrebne za donošenje poslovnih odluka. Poslovna inteligencija tipično obuhvata sljedeće elemente:

- prikupljanje, obradu i učitavanje podataka,
- skladištenje podataka,
- sintezu i analizu podataka,
- prezentaciju podataka poslovnim korisnicima.

U okviru tipičnog sistema poslovne inteligencije vrši se prikupljanje podataka iz različitih izvora, a zatim prečišćavanje, filtriranje, transformacija i smještaj u skladište podataka. Nakon punjenja skladišta podataka vrši se sinteza podataka u posebnom obliku pogodnom za analizu. Podaci se memorišu u obliku tzv. OLAP kocke (*eng. OLAP cube, OLAP – Online Analytical Processing*), koja predstavlja kolekciju numeričkih podataka (mjera) čiji je prikaz moguće realizovati iz različitih perspektiva, odnosno po različitim obilježjima. Pri pregledu podataka iz OLAP kocke, korisnik može na interaktivan način da mijenja način prikaza, nivo detalja u prikazu podataka, te da vrši analizu i raslojavanje podataka po pojedinim obilježjima izvođenjem operacija kao što su *slice and dice*, *pivot*, *drill-up* i *drill-down*. *Slice and dice* predstavlja izdvajanje (odrezivanje) željenog podskupa podataka iz OLAP kocke posmatranjem jednog ili više obilježja. *Pivot* (rotiranje podataka) predstavlja mogućnost promjene načina prezentacije podataka da bi se dobio odgovarajući način prikaza i odgovarajući pogled na podatke. Operacije *drill-up* i *drill-down* omogućavaju promjenu nivoa detalja u prikazu podataka iz OLAP kocke, odnosno promjenu nivoa agregacije numeričkih podataka od najvećeg nivoa agregacije (sumarni podaci) ka nižim nivoima agregacije (detaljniji podaci).

Poslovna inteligencija i podrška odlučivanju u poljoprivredi

Postoje značajne mogućnosti za primjenu poslovne inteligencije u oblasti poljoprivrede, kao i u bilo kojoj drugoj oblasti gdje je potrebno analizirati velike količine podataka i na osnovu njih donositi poslovne odluke. Poslovna inteligencija može doprinijeti povećanju proizvodnog potencijala i tehničke efikasnosti

poljoprivrednih preduzeća i gazdinstava zbog efektivne podrške upravljačkim, analitičkim i planskim aktivnostima (Tyrychtr i sar., 2015). Poslovna inteligencija i sistemi za podršku odlučivanju u poljoprivredi koriste se u različitim segmentima kao što su analiza i predviđanje cijena poljoprivrednih proizvoda na tržištu (Tejas i Kalpesh, 2015), određivanje potrebnog nivoa vlage u zemljištu za pojedine usjeve i lokacije na osnovu podataka o zemljištu, usjevima i meteorološkim uslovima (Celarc i Gros, 2013), analiza podataka o kupcima i konkurenciji, analiza meteoroloških i klimatskih uslova u kombinaciji sa lokalnim podacima na farmama (Krintz i sar., 2016).

Pojedina istraživanja uvode i pojam „poljoprivredne inteligencije“ koji predstavlja kombinaciju poslovne inteligencije i drugih tipova informacionih sistema koji se koriste u poljoprivredi. Poljoprivredna inteligencija u ovom kontekstu ne predstavlja konkretan proizvod ili sistem, nego određenu arhitekturu koju čine integrisane operative i upravljačke komponente, tehnologije i baze podataka, koje poljoprivrednoj zajednici omogućavaju pristup znanju u oblasti poljoprivrede (Ghadiyali i sar., 2011). Neki od ciljeva poljoprivredne inteligencije su podrška u donošenju odluka baziranom na realnim podacima, povećanje performansi kroz integraciju u poslovne procese na farmama, te bolje upravljanje podacima o kupcima i konkurenciji.

Međutim, primjena alata i metodologija poslovne inteligencije, kao ni drugih specijalizovanih poslovnih informacionih sistema u oblasti poljoprivrede, još uvijek nije na zadovoljavajućem nivou kada je riječ o malim poljoprivrednim proizvođačima i farmama, iako za to postoji veliki potencijal. Na osnovu istraživanja stanja poslovne inteligencije i upotrebe specijalizovanih poslovnih informacionih sistema u poljoprivredi na malim češkim farmama, dobijeni rezultati pokazuju da je nivo primjene ovih tehnologija na niskom nivou, bez obzira na tip proizvodnje, strukturu i veličinu farme (Tyrychtr i sar., 2015). Jedan od razloga za ovakvo stanje je što su ovakve tehnologije i sistemi još uvijek nedostupni malim proizvođačima zbog visoke cijene, ali i drugih faktora kao što su sigurnost, privatnost i zaštita podataka. Upravo iz tih razloga, postoje određena nastojanja da se razviju sistemi koji će biti pristupačniji, a koji će riješiti neke od pomenutih problema (Krintz i sar., 2016).

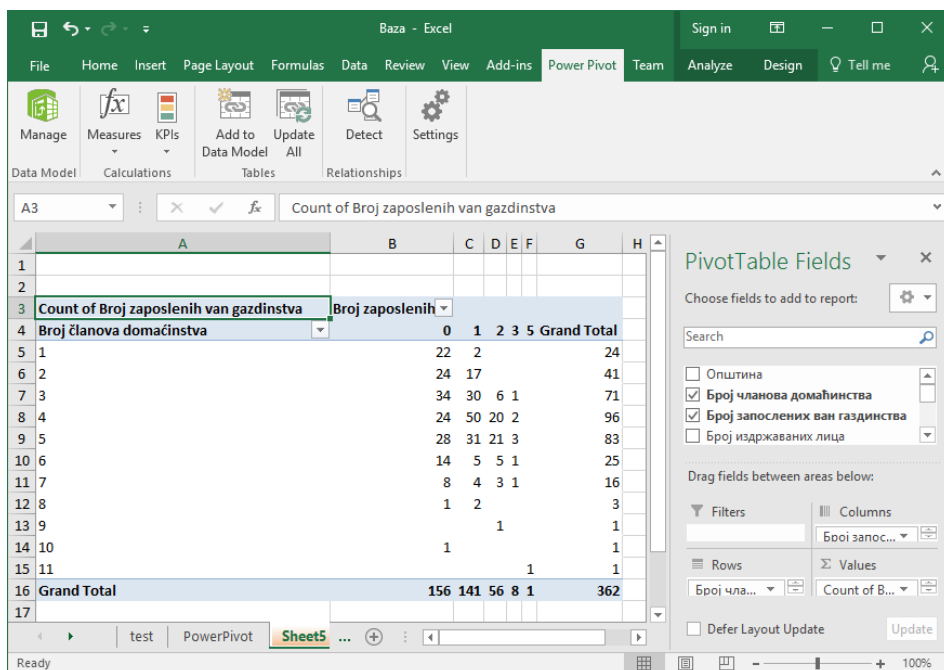
Materijal i metode rada

U okviru istraživanja predstavljenog u ovom radu istražena je literatura domaćih i inostranih autora koja se bavi tematikom poslovne inteligencije i primjenama u poljoprivredi. Empirijski dio istraživanja obavljen je na podacima koji su dobijeni u okviru istraživanja sprovedenog na 362 poljoprivredna gazdinstva u jugoistočnom dijelu Republike Srpske. Za svako gazdinstvo prikupljeni su podaci o više od 100 obilježja. Podaci su uneseni u Microsoft Excel tabelu i kao takvi predstavljaju osnovu za dalju analizu primjenom standardnih Excel alata, kao i specijalnih Excel dodataka koji se koriste za analizu podataka korišćenjem alata poslovne inteligencije. Ovi dodaci dostupni su u novijim verzijama Excela, počevši od verzije 2013, a zajedno se nazivaju *Excel Power BI* i omogućavaju kreiranje tzv. *Self-service Business Intelligence* sistema, odnosno samostalno kreiranje jednostavnijih sistema poslovne inteligencije od strane menadžera ili poslovnih analitičara, bez potrebe za angažovanjem IT stručnjaka. Pojedinačni dodaci iz ove grupe nazivaju se *Power Pivot*, *Power Query*, *Power View* i

Power Map. Pomoću pomenutih dodataka moguće je realizovati operacije koje se tipično realizuju i u kompleksnim sistemima poslovne inteligencije, a obuhvataju preuzimanje podataka iz različitih izvora, prečišćavanje i transformaciju podataka, kreiranje modela podataka sa odgovarajućim relacijama među podacima, kreiranje kalkuliranih mjera i ključnih indikatora performansi, generisanje izvještaja i vizuelizaciju podataka pomoću tabela, grafika i mapa. U jednostavnom primjeru koji je naveden u ovom radu prikazan je izvještaj generisan korišćenjem dodatka Power Pivot.

Rezultati istraživanja i diskusija

Na slici 1 prikazan je primjer kreiranog izvještaja korišćenjem pivot table. U pitanju je baza podataka sa 362 domaćinstva i preko 100 obilježja od kojih su samo dva obuhvaćena: *Broj članova domaćinstva* i *Broj zaposlenih van gazdinstva*. Ovaj izvještaj pruža uvid u distribuciju ukupnog broja domaćinstava prema broju članova, zatim prema broju zaposlenih van gazdinstva, ali i jasan uvid u distribuciju uz istovremeno korišćenje oba obilježja. Na slici 1 lako je uočljivo da se najveći broj domaćinstava sastoji od četiri člana, te da njih 156 nema niti jednog zaposlenog člana izvan gazdinstva.



Slika. 1. Primjer generisanja izvještaja korišćenjem pivot table
Figure. 1. An example of generating report using pivot table

Izvršetak je kreiran izborom željenih obilježja i njihovim lociranjem na odgovarajuće pozicije u pivot tabeli, što se izvodi pomoću elemenata prikazanih na desnoj strani prozora sa slike 1. U listi obilježja nalaze se sva obilježja iz modela podataka, kao i eventualno dodatno kreirane kalkulisane mjere. Pozicioniranjem obilježja na lokaciju redova, kolona ili vrijednosti, te podešavanjem dodatnih parametara (sumiranje, brojanje, prosjek, itd.) za prikazane vrijednosti, omogućava se kreiranje izvještaja prilagođenog konkretnim potrebama. Pošto je u pitanju veliki broj obilježja svakog gazdinstva, broj izvještaja koji prikazuju podatke iz različitih perspektiva je skoro neograničen, što omogućava analitičarima da izvještaj skroje po svojoj mjeri i prikažu podatke koji su im najinteresantniji. Kod klasičnih sistema izvještavanja, ovo najčešće nije moguće bez dodatne intervencije IT osoblja jer su izvještaji u takvim sistemima obično fiksne strukture koja je određena inicijalnim zahtjevima kod projektovanja sistema.

Zaključak

Primjena modernih IT alata je svakodnevica u radu današnjeg poslovnog čovjeka, bez obzira na oblast i djelokrug rada. Za uspjeh u obavljanju posla, a pogotovo za donošenje ključnih poslovnih odluka, bitno je raspolagati tačnim i pravovremenim informacijama iz svih poslovnih procesa. Savremene tehnologije u oblasti senzora, elektronike i računarstva omogućavaju relativno jeftina rješenja za integraciju podataka iz svih poslovnih procesa i stvaraju pretpostavke za efikasnu analizu i izvještavanje u funkciji podrške menadžmentu. Poljoprivreda je oblast u kojoj je potreba za preciznim i sveobuhvatnim podacima sa terena oduvijek izražena, a današnje tehnologije omogućavaju da se oni skoro u realnom vremenu prikupljaju, analiziraju i stavljaju na raspolaganje zainteresovanim stranama. Primjena tehnologija i alata koji su ukratko prezentovani u ovom radu, trebalo bi da omogući savremenim menadžerima i donosiocima odluka u poljoprivredi da steknu bolji uvid u poslovanje organizacije kroz adekvatnu prezentaciju i vizuelizaciju ključnih poslovnih informacija, te da na osnovu toga donose i kvalitetnije odluke koje će rezultovati poslovnim uspjehom.

Literatura

- Moskvins, G., Spakovica, E., & Moskvins, A. (2008). Development of Intelligent Technologies and Systems in Agriculture. In Proceedings of 7th International Conference Engineering for Rural Development: 108-113.
- Sørensen, C. G., & Bochtis, D. D. (2010). Conceptual model of fleet management in agriculture. *Biosystems Engineering*, 105(1), 41-50.
- Ghadiyali, T., Lad, K., & Patel, B. (2011, February). Agriculture intelligence: an emerging technology for farmer community. In *Emerging Applications of Information Technology (EAIT)*, 2011 Second International Conference on (pp. 313-316). IEEE.
- Tejas, G., & Kalpesh, L. (2015). Sustainable Decision Support System for Crop Cultivation. *International Journal of Agricultural Science and Technology* 3 (2): 36-45.

- Ilie, I., & Gheorghe, G. I. (2016). Embedded Intelligent Adaptronic and Cyber-Adaptronic Systems in Organic Agriculture Concept for Improving Quality of Life. *Acta Technica Corviniensis-Bulletin of Engineering*, 9(3), 119-122.
- Krintz, C., Wolski, R., Golubovic, N., Lampel, B., Kulkarni, V., Roberts, B., & Liu, B. (2016). SmartFarm: Improving agriculture sustainability using modern information technology. *ACM SIGKDD DSFEW*.
- Celarc, S., & Gros, M. (2013). Calculation of the water balance and analysis of agriculture drought data using a Business Intelligence (BI) system. In *GIL Jahrestagung* (pp. 35-38).
- Tyrychtr, J., Ulman, M., & Vostrovský, V. (2015). Evaluation of the state of the Business Intelligence among small Czech farms. *Agricultural Economics*, 61(2), 63-71.
- Waga, D., & Rabah, K. (2014). Environmental conditions' big data management and cloud computing analytics for sustainable agriculture. *World Journal of Computer Application and Technology*, 2(3), 73-81.
- Garg, R., & Aggarwal, H. (2016). Big Data Analytics Recommendation Solutions for Crop Disease using Hive and Hadoop Platform. *Indian Journal of Science and Technology*, 9(32).

USING BUSINESS INTELLIGENCE FOR DATA ANALYSIS AND DECISION SUPPORT IN AGRICULTURE

Grujica Vico¹, Danijel Mijic², Radomir Bodiroga¹

Abstract

The aim of this paper is to investigate and to present possibilities of using business intelligence in agriculture. We shortly introduced the term of business intelligence, presented some of its application in agriculture, and also presented some simple tools and its application for data analysis on a concrete set of data on small farms. By using these tools, decision makers are able to create custom data views from different perspectives, according to their specific needs and using their own skills. This should result in getting timely business information tailored to their needs.

Key words: business, intelligence, decision making, agriculture, analysis

¹University of East Sarajevo, Faculty of Agriculture, Vuka Karadzica 30, East Sarajevo, Bosnia and Herzegovina (vicogrujica@yahoo.com);

²University of East Sarajevo, Faculty of Electrical Engineering, Vuka Karadzica 30, East Sarajevo, Bosnia and Herzegovina